

A Utilização da Regressão Linear Como Ferramenta Estratégica Para a Projeção dos Custos Produção

MIGUEL LOPES DE OLIVEIRA FILHO

Resumo:

O ambiente em que as organizações convivem está em contínua mudança, e a busca pela melhor forma de sobrevivência tem se tornado uma tarefa cada vez mais difícil. Os consumidores estão em busca de produtos que lhes ofereçam alta qualidade por um menor custo. Na luta pela sobrevivência, torna-se essencial a construção de cenários capazes de suportarem a incorporação de todas as rotinas empresariais, com a finalidade de se tornarem uma valiosa ferramenta de apoio para a definição de estratégias contra a concorrência. O planejamento e organização na construção de cenários permitem visualizar as possíveis posições futuras e caminhos disponíveis para deslocar-se para uma nova posição no mesmo cenário ou em direção a novos cenários. O aprendizado gerado naturalmente da experiência de construir e de se capacitar a construir cenários, permite também enxergar oportunidades e ameaças que de outra forma permaneceriam ocultas aos gestores das empresas. Utilizando-se da metodologia estatística - regressão linear - foi criado um exemplo com a finalidade de evidenciar a utilidade e aplicação da regressão linear como fonte de projeção dos custos de produção industriais baseando-se nos custos incorridos de períodos anteriores. Criando-se com isso uma expectativa sobre os custos a serem incorridos no futuro.

Área temática: *Gestão Estratégica de Custos*

TRABALHO 278

**A UTILIZAÇÃO DA REGRESSÃO LINEAR COMO FERRAMENTA
ESTRATÉGICA PARA A PROJEÇÃO DOS CUSTOS PRODUÇÃO**

RESUMO

O ambiente em que as organizações convivem está em contínua mudança, e a busca pela melhor forma de sobrevivência tem se tornado uma tarefa cada vez mais difícil. Os consumidores estão em busca de produtos que lhes ofereçam alta qualidade por um menor custo. Na luta pela sobrevivência, torna-se essencial a construção de cenários capazes de suportarem a incorporação de todas as rotinas empresariais, com a finalidade de se tornarem uma valiosa ferramenta de apoio para a definição de estratégias contra a concorrência.

O planejamento e organização na construção de cenários permitem visualizar as possíveis posições futuras e caminhos disponíveis para deslocar-se para uma nova posição no mesmo cenário ou em direção a novos cenários. O aprendizado gerado naturalmente da experiência de construir e de se capacitar a construir cenários, permite também enxergar oportunidades e ameaças que de outra forma permaneceriam ocultas aos gestores das empresas.

Utilizando-se da metodologia estatística - regressão linear - foi criado um exemplo com a finalidade de evidenciar a utilidade e aplicação da regressão linear como fonte de projeção dos custos de produção industriais baseando-se nos custos incorridos de períodos anteriores. Criando-se com isso uma expectativa sobre os custos a serem incorridos no futuro.

Projeção de Custos; Regressão Linear E Gestão de Custos

Gestão Estratégica de Custos;

A UTILIZAÇÃO DA REGRESSÃO LINEAR COMO FERRAMENTA ESTRATÉGICA PARA A PROJEÇÃO DOS CUSTOS PRODUÇÃO

INTRODUÇÃO

Nos últimos anos o ambiente empresarial vem passando por um período de grandes mudanças. A sobrevivência das organizações no mercado atual depende de sua competitividade, que hoje é função direta da produtividade e qualidade da empresa. O dinamismo e a crescente competitividade no mundo dos negócios colocam em risco a vida das empresas que não questionarem seus métodos tradicionais de gerenciamento, desenvolvimento de novos produtos e serviços e o controle da qualidade de produção.

Considerando o ambiente globalizado e a conseqüente competitividade entre as empresas, essas organizações estão aumentando a busca por táticas para atingir seus objetivos de forma a estarem sempre à frente de seus concorrentes. E sendo seus produtos a principal arma para vencer essa “batalha”, as empresas estão sempre em busca do fortalecimento das suas estratégias produtivas, focando sempre a redução dos custos de produção de forma que a qualidade dos produtos permaneça a mesma.

Mudanças significativas na qualidade ou no custo de insumos podem sinalizar a oportunidade para um administrador obter vantagem de custo através de um novo processo de produção.

REGRESSÃO LINEAR

A análise de regressão tem por objetivo descrever através de um modelo matemático, as relações existentes entre duas ou mais variáveis, a partir de n observações dessas variáveis.

As variáveis independentes que são acrescentadas ao modelo têm como finalidade melhorar a capacidade de predição em confronto com a regressão linear simples.

Regressão Múltipla

A maioria dos problemas práticos envolve mais de uma variável para fins de previsão. Por exemplo, caso alguém desejasse prever uma variável (y) por meio de outras variáveis (x_1 e x_2) o problema seria descobrir o plano que melhor se ajustasse, no sentido dos mínimos quadrados, a um diagrama de dispersão de pontos em três dimensões.

Segundo Horngren, Foster & Datar (1997:255) em alguns casos, a estimativa satisfatória de uma função de custo pode basear-se em apenas uma variável independente, tal como horas-máquina; em muitos outros casos, porém, basear a estimativa em mais de uma variável independente é economicamente mais viável e aumenta a precisão da estimação dos valores.

A análise de regressão múltipla é a técnica mais adequada quando se deseja investigar simultaneamente os efeitos que várias variáveis independentes poderão causar na variável dependente. Mesmo quando o interesse está voltado para uma única variável independente é aconselhável incluir outras variáveis capazes de afetar a variável dependente. Pois em regressão linear múltipla todas as mudanças ocorridas em uma variável podem ser explicadas por uma referência a mudanças em várias outras variáveis.

A análise de regressão linear múltipla é uma extensão da análise de regressão simples. As aplicações com regressão múltipla envolvem duas ou mais variáveis independentes para estimar o valor da variável dependente. As variáveis independentes, denotadas por x_1 , x_2 e x_k formam a seguinte equação de regressão múltipla:

Figura 1

$$y_c = a + b_1x_1 + b_2x_2 \dots b_kx_k$$

Onde:

y_c = representa o "valor calculado de y ".

a = intercepto- y .

b_I = números de coeficientes angulares.

K = número de variáveis independentes.

A equação de regressão múltipla identifica a melhor linha ajustante baseada no método dos mínimos quadrados. Na análise de regressão múltipla, a melhor linha ajustante é uma linha através de um espaço n -dimensional. Quando se tratar de duas variáveis independentes, o espaço é tridimensional.

Na regressão linear múltipla com três variáveis independentes resultará em um plano em vez de uma reta. E quando há k variáveis independentes resultará em um hiperplano.

No caso do plano de regressão os dados pontuais se apresentam dispersos em torno do plano, ao invés de estarem ao redor da reta como acontece com a regressão linear simples.

Como a equação de qualquer plano no espaço tridimensional determinado pelas variáveis y , x_1 e x_2 pode escrever-se na forma: $y_c = a + b_1x_1 + b_2x_2$. o problema é estimar os três parâmetros a , b_1 e b_2 pelo método dos mínimos quadrados, com a utilização das seguintes equações:

Muito embora os valores de a e dos diversos b_I sejam todos estimativas de constantes da equação de regressão, nos programas de estatística informatizados o termo "constante" refere-se ao valor a do intercepto. Na análise de regressão múltipla, este é o valor estimado da variável dependente y , dado que todas as variáveis independentes sejam iguais a zero.

Figura 2

$$\begin{aligned} an + b_1 \sum x_1 + b_2 \sum x_2 &= \sum y \\ a \sum x_1 + b_1 \sum x_1^2 + b_2 \sum x_1 x_2 &= \sum x_1 y \\ a \sum x_2 + b_1 \sum x_1 x_2 + b_2 \sum x_2^2 &= \sum x_2 y \end{aligned}$$

Partindo-se do sistema de equações a resolução algébrica da equação de regressão linear múltipla, em relação a a , b_1 e b_2 , também poderá ser resolvida através das fórmulas:

Figura 3

$$b_1 = \frac{(\sum x_1^* y^*) (\sum x_2^{*2}) - (\sum x_2^* y^*) (\sum x_1^* x_2^*)}{(\sum x_1^{*2}) (\sum x_2^{*2}) - (\sum x_1^* x_2^*)^2}$$

$$a = \bar{y} - b_1 \bar{x}_1 - b_2 \bar{x}_2$$

$$b_2 = \frac{(\sum x_2^* y^*) (\sum x_1^{*2}) - (\sum x_1^* y^*) (\sum x_1^* x_2^*)}{(\sum x_1^{*2}) (\sum x_2^{*2}) - (\sum x_1^* x_2^*)^2}$$

Considerando que:

Figura 4

$$x_1^* = (x_1 - \bar{x}_1) \quad x_2^* = (x_2 - \bar{x}_2) \quad y^* = (y_i - \bar{y})$$

Onde:

- b = Declividade da linha de regressão (**coeficiente angular**);
- a = Ponto de intersecção da linha da regressão linear com o eixo do y ., quando os valores de x forem igual a 0 (zero) (**intercepto-y**).

Finalidade da equação de regressão

- Estimar valores de uma variável (dependente), com base em valores conhecidos das outras (independentes);
- Explicar valores de uma variável (dependente) em termos das outras (independentes) – (Causa e efeito);
- Predizer valores futuros de uma variável (dependente), ou seja, com base em uma ou mais variável explicar o potencial futuro de outra.

Vale salientar que:

- O valor calculado de y (estimado) trata-se de uma relação média e não exata;
- Não se devem incluir valores para as variáveis x 's que não se encontrem nos dados do modelo em estudo, pois se deve levar em consideração que a equação suporta apenas àqueles dados.

Inferências sobre o coeficiente angular da reta ou plano de regressão

A inferência sobre o coeficiente angular tem como função testar se os parâmetros não são nulos, ou seja, é a verificação das situações onde as variáveis são relacionadas ou não.

Para se efetuar o teste individual do coeficiente de regressão parcial será utilizada a distribuição t , desde que a quantidade de observações seja menor que 30 ($n < 30$) e deverão obedecer as seguintes hipóteses:

$$H_0 : B_i = 0 \rightarrow \text{Hipótese nula;}$$

$H_1 : B_i \neq 0 \rightarrow$ Hipótese alternativa.

O teste deverá ser efetuado individualmente para cada coeficiente, com a finalidade de determinar se um ou mais coeficientes é significante.

Coefficiente de correlação

O estudo da correlação tem por objetivo medir e avaliar o grau de relação existente entre duas ou mais variáveis na esperança de que qualquer relação encontrada possa ser usada no sentido de fazer estimativas ou predições de uma das variáveis particulares, ou seja, é o número que resume o grau de relacionamento entre a variável dependente e uma ou mais variáveis independentes. E esse grau de correlação será medido através das disposições dos pontos referentes as variáveis independentes e a variável dependente numa reta ou um plano.

Coefficiente de determinação

Este coeficiente indica a proporção da variância da variável dependente que pode ser estatisticamente atribuída ao conhecimento de uma ou mais variáveis independentes.

O coeficiente de determinação mensura a relação existente entre a variável dependente e as variáveis independentes. Indicando quantos por cento a variação explicada pela regressão representa da variação total (população).

Quando:

- $r^2 = 1 \rightarrow$ Todos os pontos observados se situam exatamente sobre a reta de regressão (ajuste perfeito), ou seja, as variações de y são 100% explicadas pela variação dos x 's através da função especificada, não havendo desvios em torno da função estimada.
- $r^2 = 0 \rightarrow$ Conclui-se que as variações de y são exclusivamente aleatórias e a introdução das variáveis x 's no modelo não incorporará informação alguma sobre as variações de y .

Coefficiente de determinação ajustado

Com a finalidade de tornar os r^2 comparáveis, utiliza-se o coeficiente de determinação ajustado, pois é uma maneira de expressar o coeficiente de determinação em termos de variância e não de variação.

É uma prática comum em regressão múltipla e análise de correlação informar o coeficiente de determinação ajustado. O qual é simbolizado por \bar{r}^2 , e ler-se como "**r barra ao quadrado**". Este ajuste estatístico serve como um grande poder explicativo para o número de graus de liberdade. Toda vez que se adiciona uma variável independente ao modelo, perde-se um grau de liberdade, porque cada variável requer o cálculo de outro coeficiente angular.

O coeficiente de determinação ajustado servirá como medida de compensação para cada variável adicionada que não seja bastante representativa ao modelo a ponto de justificar a perda de um grau de liberdade. E assim, o valor de \bar{r}^2 diminuirá. Se diminuição for muito acentuada, significa dizer que a variável acrescentada ao modelo deverá ser excluída, pois não tem relação com as demais variáveis do modelo. Em casos extremos, o coeficiente de determinação ajustado pode vir de fato a se tornar menor que zero.

Multicolinearidade

É a correlação existente entre as variáveis explicativas, incluídas na equação de um determinado modelo, ou seja, a multicolinearidade ocorre quando duas variáveis medem aproximadamente a mesma intensidade explicativa ao ponto que a correlação existente entre elas é quase perfeita. Quando tal correlação acontece, a eficiência dos parâmetros estimados é significativamente afetada, tornando-os instáveis. Tem como principal implicação o aumento da variância da estimativa e, conseqüentemente, ocasiona também o aumento do erro-padrão. Com isso o valor da estatística *t* sofre redução, levando às vezes de forma totalmente equivocada, a aceitação da hipótese nula prejudicando a interpretação dos resultados desejados.

A multicolinearidade é uma questão de grau e não de natureza. A distinção significativa não está entre a presença ou a ausência de multicolinearidade, mas entre seus vários graus.

Em uma explicação mais clara podemos tomar como exemplo a seguinte equação de regressão linear múltipla: $y_c = a + b_1x_1 + b_2x_2$. Considerando o valor de $x_2 = 2x_1$, para cada mudança ocorrida no valor de x_1 , conseqüentemente o valor de x_2 será acompanhado proporcionalmente a essa mudança. Isso nos levar a crer que, não é possível separar as variações ocorridas em y_c decorrentes das alterações sofridas pela variável explicativa x_1 , sem que haja uma influência da variável independente x_2 . Diante de tal fato fica registrada a impossibilidade de estimação dos parâmetros de modelo em estudo.

A dificuldade maior girará em torno de situações em que a correlação existente entre as variáveis independentes for altamente elevada, porém não perfeita. Essa situação de transtorno envolverá a dificuldade de se isolar os efeitos das variáveis explicativas colineares e, conseqüentemente, formará a dificuldade de interpretação dos resultados obtidos sobre àqueles dados.

Uma das hipóteses da regressão linear múltipla é de assegurar a impossibilidade da existência de relação linear entre qualquer das variáveis explicativas, ou seja, elas têm de ser linearmente independentes.

Assim, pode ocorrer que entre as variáveis explicativas exista uma correlação maior do que se espera teoricamente, como decorrência da seleção de uma amostra que inclua apenas observações referentes a esses períodos. Muita atenção tem sido dada ao problema da multicolinearidade, sem que o mesmo cuidado seja dispensado a outra situação tão problemática quanto esta, ou seja, a utilização de amostras com reduzido número de elementos. Todos os problemas associados a multicolinearidade devem ser sempre reavaliados diante da possibilidade de se estar trabalhando com um número insuficiente de observações.

A utilização de valores defasados de algumas das variáveis explicativas como novas variáveis independentes também pode ocasionar o problema da multicolinearidade.

De acordo com Matos (2000:124-125), existem três maneiras de se tratar o envolvimento da multicolinearidade:

- **Ausência de multicolinearidade** – Ocorre quando as variáveis independentes não estão correlacionadas entre si, ou seja, a correlação entre as variáveis explicativas é nula.
- **Multicolinearidade perfeita** – Ocorre quando a correlação entre as variáveis explicativas é igual a 1 ou -1 . Tornando impossível o cálculo das estimativas dos parâmetros.
- **Multicolinearidade imperfeita** – Ocorre quando a correlação entre as variáveis explicativas situa-se entre 0 e 1 ou entre -1 e 0.

Segundo Diaz (2000:143) algumas providências devem ser tomadas para facilitar o modelo em estudo no caso de detecção de multicolinearidade, e dentre essas soluções podem ser citadas:

- **Incorporar Outras Informações ao Modelo**

A solução geralmente apontada como ideal seria aumentar o tamanho da amostra. Todavia, como alguns autores destacam, não bastaria incorporar dados com as mesmas características dos que compõem a matriz X. O problema pode ser decorrente da utilização de uma amostra limitada, por exemplo, a um período em que as variáveis explicativas estavam sendo afetadas por algum fato político. Assim, se mais algumas observações de períodos em que essa influência se mantém forem incluídas, certamente, não será possível solucionar o problema. De outra forma, sabe-se como é difícil, no Brasil, construir uma amostra de qualidade. Afinal, após tantos planos e mudanças nos conceitos de muitas variáveis, coletar um número razoável de observações compatíveis pode ser considerada uma tarefa, até certo ponto, impossível.

- **Reespecificar o Modelo**

Dadas as dificuldades apresentadas anteriormente, a forma popularmente utilizada para solucionar o problema é eliminar uma das variáveis explicativas que estão correlacionadas. Entretanto, essa solução pode criar um problema de especificação, ou seja, omissão de variável relevante. Caso o verdadeiro coeficiente dessa variável seja estatisticamente diferente de zero, a exclusão poderá gerar um viés nos coeficientes estimados das demais variáveis explicativas. Assim, esse não é um procedimento recomendável.

Na verdade, conforme destacado por Maddala (1992), seria possível reespecificar o modelo por meio da introdução de transformações nas variáveis, tais como as utilizadas na solução dos problemas de autocorrelação e heteroscedasticidade. Todavia, ele faz questão de ressaltar que, apesar de esse recurso reduzir a correlação entre as variáveis explicativas, diminuindo os impactos da presença de multicolinearidade, esse tipo de procedimento não é o mais adequado na solução desse problema.

Conforme se verifica facilmente, as alternativas apresentadas em termos de reespecificação do modelo, na verdade, podem até contribuir para contornar o problema, porém não podem ser consideradas como soluções, pois acabam introduzindo outras fontes de distorções indesejáveis. Isso reforça a idéia de que a multicolinearidade é um dos problemas mais difíceis de ser tratado.

Autocorrelação serial

Segundo Gujarati (2000:401) a autocorrelação é a correlação entre membros de séries de observações ordenadas no tempo, ou seja, é a dependência temporal dos valores sucessivos dos resíduos.

Para Matos (1999:135) existindo a autocorrelação entre os resíduos, as estimativas de mínimos quadrados ordinários dos parâmetros não apresentam variância mínima, provocando incorreção nos intervalos de confiança.

Heteroscedasticidade

Um pressuposto muito importante em qualquer modelo de regressão linear é que as perturbações (resíduos) que aparecem na função de regressão da população devam ser homoscedásticas, ou seja, todos os resíduos devem ter variância uniforme. E quando isso não acontece ocorre a heteroscedasticidade.

Segundo Matos (1999:147) as principais conseqüências da heteroscedasticidade num determinado modelo de regressão é que o método dos mínimos quadrados não gera estimativas de parâmetros eficientes ou de variância mínima, o que implica erros padrões viesados e incorreção dos testes t e F e dos intervalos de confiança.

A IMPORTÂNCIA DOS CUSTOS COMO FATOR PRIMORDIAL NA TOMADA DE DECISÕES

É através dos custos que os gestores tomam a maior parte das decisões em uma organização, além disso, os custos produzem informações destinadas a auxiliar as funções de determinação de desempenho, de planejamento e controle das operações empresariais.

Segundo Atkinson at. al. (200:51) as empresas que não procurarem ferramentas alternativas para dimensionar seus atuais sistemas de custos correm o risco de estarem fornecendo informações altamente distorcidas para as tomadas de decisões. Os sistemas tradicionais falham ao não atribuírem, acuradamente, os custos elevados e crescentes de seus recursos indiretos e de apoio exigidos desde o início do processo até a comercialização do produto final.

Atkinson at. al. (200:52) diz ainda que a maioria dos gestores, tanto das empresas industriais, comerciais ou de serviços, considerando o atual ambiente competitivo, estão cada vez mais empenhados em utilizar ferramentas que proporcionem informações precisas e relevantes sobre seus custos efetivos. As necessidades por informações qualificadas e precisas sobre os custos levam os gestores a:

- A ajudarem os engenheiros a projetarem produtos que podem ser fabricados eficientemente.
- Avisar onde são necessárias melhorias em qualidade, eficiência e rapidez nas operações de produção.
- Orientar as decisões sobre *mix* de produtos.
- Escolher entre fornecedores alternativos.
- Negociar com os clientes sobre preços, especificações do produto, qualidade, entrega e serviços.

Os sistemas de custeio que não implementam ferramentas alternativas como apoio tendem a introduzir erros que, de certa forma, estão muito longe de refletir os aspectos econômicos das operações atuais de uma organização, causando, com isso, tomadas de decisões incorretas.

Os gestores, freqüentemente estão necessitando de posições sobre os custos de produção com a finalidade de terem um suporte para tomarem suas decisões. Nesse contexto Atkinson et. al. (200:124-125) descreve como alguns gerentes utilizam as informações extraídas dos custos para suportarem suas decisões:

- “Gerentes de produto da *Procter & Gamble* avaliaram a demanda do mercado e os dados do custo de seus próprios produtos, assim como as marcas de cereais de seus concorrentes, antes de decidirem diminuir seus preços em meados de 1996.
- A comparação dos custos de produção, entre as várias fábricas da *General Motors*, foi um passo decisivo na escolha daqueles que precisavam ser fechadas em 1994.
- Decisões periódicas sobre rotas e preços de passagens aéreas exigem dos gerentes da *American Airlines* avaliar os custos de remanejamento de aviões e funcionários em uma rota, comparando-os com as condições da demanda do mercado, que determinam as receitas.
- O plano de incentivo de participação nos ganhos das fábricas de peças de máquinas de lavar e secar da *Whirlpool Corporation* precisa pagar o bônus aos operários que conseguirem reduções dos custos de fabricação proporcionais ao **volume de produção**.
- O excelente controle das operações do hospital *Humana Corporation, Inc.* exige que seus gerentes mantenham uma verificação criteriosa no montante dos custos orçados comparados com a quantia gasta por cada departamento, assim como o reembolso dos custos pelas empresas de seguros.”

Os custos de produção influenciam boa parte das decisões referentes aos preços praticados e também no *mix* de produção.

Como exemplo da utilização da regressão linear para a estimativa dos custos de produção serão utilizados os dados da tabela abaixo. Para tanto vamos considerar que, determinada empresa deseja saber o comportamento dos seus custos fixos (**que é a variável dependente - y**) projetados para os próximos 12 (doze) meses em função das variáveis independentes, que são:

Horas de mão-de-obra direta (x_1)

Horas-máquina (x_2)

Para fins de análise iremos levar em consideração as seguintes hipóteses, contando com um nível de significância de 5%:

- $H_0 : \beta_1 = \beta_2 = 0$ (Rejeita-se a regressão);
- $H_1 : \beta_1 = \beta_2 \neq 0$ (Aceita-se a regressão);

Tabela 1

Mês	Custos Indiretos de Fabricação Em R\$ 1.000	Horas de mão-de-obra direta	Horas Máquinas
1	123,1	211	1240
2	124,3	215	990
3	89,3	280	240
4	141,3	500	1280
5	112,8	210	921
6	108,1	200	680
7	143,9	620	1080
8	124,2	320	980
9	110,1	430	830
10	111,7	215	980
11	123,8	260	1260
12	123,5	362	1150

Para fins de cálculo da regressão linear múltipla foi utilizado o instrumento “regressão” constante de análise de dados do Excel 2000, o resultado da análise de regressão foi o seguinte:

RESUMO DOS RESULTADOS DA REGRESSÃO

Tabela 2

<i>Estatística de regressão</i>	
R múltiplo	0,9348889
R-Quadrado	0,8740172
R-quadrado ajustado	0,8460211
Erro padrão	5,794829
Observações	12

O R-múltiplo está indicando que medida de grau de associação (coeficiente de correlação) entre a variável dependente e as variáveis independentes, é de aproximadamente 93%.

O R-quadrado e o R-quadrado ajustado (coeficiente de determinação) indicam que a variação sofrida pela variável dependente está explicada pelas variáveis independentes em 87% (R-quadrado) e 85% (R-quadrado ajustado).

TABELA ANOVA

Tabela 3

<i>itens</i>	<i>gl</i>	<i>SQ</i>	<i>MQ</i>	<i>F</i>	<i>F de significação</i>
Regressão	2	2096,6821	1048,3411	31,219169	8,94E-05
Resíduo	9	302,22039	33,580044		
Total	11	2398,9025			

Como o F de significância da tabela ANOVA é menor que o F de significância adotado conclui-se por aceita a regressão (H_1) e rejeitar a hipótese nula (H_0)

Tabela 4

<i>Itens</i>	<i>Coefficientes</i>	<i>Erro padrão</i>	<i>Stat t</i>	<i>valor-P</i>	<i>95% inferiores</i>	<i>95% superiores</i>
Interseção	68,6159014	6,675706593	10,278448	2,85E-06	53,5143924	83,71741039
Variável X 1	0,047795155	0,013255086	3,6057973	0,00569654	0,017810043	0,077780266
Variável X 2	0,036969161	0,006151834	6,0094532	0,00020017	0,023052734	0,050885587

Tanto os intervalos de confiança como os valores constantes do P-value indicam que todos os coeficientes incorporados ao modelo são bons estimadores.

RESULTADOS DOS RESÍDUOS

Tabela 5

<i>Observação</i>	<i>Y previsto</i>	<i>Resíduos</i>	<i>Resíduos padrão</i>
1	124,542438	-1,44243815	-0,275189374
2	115,491329	8,80867137	1,680524576
3	90,8711433	-1,57114328	-0,299743829
4	139,834004	1,46599569	0,279683698
5	112,701481	0,098519222	0,018795567
6	103,313962	4,786038464	0,913083815
7	138,175591	5,724409226	1,092106855
8	120,140128	4,059871721	0,774545209
9	119,852221	-9,75222122	-1,860535687
10	115,121637	-3,42163703	-0,65278234
11	127,623784	-3,82378395	-0,729504215
12	128,432282	-4,93228208	-0,940984275

Os valores dos custos que desejamos como estimativa para os doze meses seguintes são os constantes da coluna Y previstos.

RESULTADOS DA PROBABILIDADE

Tabela 6

<i>Percentil</i>	<i>Y</i>
4,16666667	89,3
12,5	108,1
20,83333333	110,1
29,16666667	111,7
37,5	112,8
45,83333333	123,1
54,16666667	123,5
62,5	123,8
70,83333333	124,2
79,16666667	124,3
87,5	141,3
95,83333333	143,9

CONCLUSÃO

O trabalho apresentado teve como pressuposto básico discutir o uso da regressão linear como ferramenta de estimativa dos custos de produção, reconhecendo na mesma um caráter de necessidade gerencial, porém sugerindo uma nova perspectiva. A principal preocupação foi de inseri-la sob o prisma da intervenção estratégica.

Muitos problemas envolvendo os custos de produção podem ser facilmente solucionados através da utilização dos métodos quantitativos, e a regressão linear é uma das maneiras mais prática em que o gestor poderá fazer estimativas de custos para tomar decisões que envolvam dados futuros.

As mudanças ocorridas na economia mundial nos últimos anos pressionaram as organizações industriais a se adequarem no que diz respeito a sua rotina operacional, objetivando manter-se no mercado de uma forma completamente competitiva. A globalização da economia veio acentuar a concorrência entre companhias, que cada vez mais se empenham na elaboração de planos e estratégias, visando gerar resultados satisfatórios, sem perder a qualidade do seu produto.

As ferramentas utilizadas pelas indústrias para gerir seus custos, visam não só sua redução, mas também sua real mensuração, objetivando colocar seus produtos no mercado sem prejudicar a boa qualidade e custo do mesmo permanecendo atuante e competitivo num mercado cada vez mais globalizado.

BIBLIOGRAFIA

ATKINSON, Anthony A. et al. *Contabilidade gerencial*. Tradução de André Olímpio Mosselman Du Chenoy Castro, São Paulo: Atlas, 2000.

BERENSON, Mark L; LEVINE, David M. *Basic business statistics: concepts and applications*. 6 ed. Englewood Cliffs, New Jersey: Prentice Hall, 1996

CARMO, Heron Carlos Esvael do; DIAZ, Maria Dolores Montoya. *Análise da base de dados e utilização de variáveis binárias (DUMMY)*. In: VASCONCELLOS, Marco Antonio Sandoval & Alves, Denisard (Coords.). *Manual de Econometria*, São Paulo: Atlas, 2000. cap.6 p. 83-104.

COHEN, Jacob; COHEN, Patricia. *Applied multiple regression/correlation analysis for the behavioral sciences*. Hillsdale, New Jersey: Lawrence Erlbaum, 1975.

DIAZ, Maria Dolores Montoya. Multicolinearidade. In: VASCONCELLOS, Marco Antonio Sandoval & Alves, Denisard (Coords.). *Manual de Econometria*, São Paulo: Atlas, 2000. cap.6 p. 139-145

FONSECA, Jairo Simon da; MARTINS, Gilberto de Andrade; TOLEDO, Geraldo Luciano. *Estatística aplicada*. 2. ed. São Paulo: Atlas, 1991.

FONSECA, Jairo Simon da. Contribuição ao emprego de modelos de regressão no processo de previsão, São Paulo, 1974. 58p Tese (Doutorado) - Faculdade de Economia, Administração e Contabilidade da Universidade De São Paulo.

FREUND, John E.; SIMON, Gary A. *Estatística aplicada à economia, administração e contabilidade*. Tradução de Alfredo Alves de Farias, 9 ed. Porto Alegre: Bookman, 2000.

GUJARATI, Damodar N. *Basic econometrics*, 3 ed. New York: McGraw-Hill, 1995.

HILL, Carter, GRIFFITHS, William; JUDGE, Georege. *Econometria*, Tradução de Alfredo Alves de Farias, São Paulo: Saraiva, 2000.

HOEL, Paul G. *Estatística elementar*, Tradução de Carlos Roberto Vieira Araújo, São Paulo: Atlas, 1977.

HORNGREN, Charles T., FOSTER, George; DATAR, Srikant M. *Contabilidade de custos*. Tradução de José Luiz Paravato, 9. ed. Rio de Janeiro: LTC, 1997.

JAMES, D.E.; THROSBY. *Métodos quantitativos aplicados à economia*, Tradução de Carlos Roberto Vieira Araújo, São Paulo: Atlas, 1977.

JOHNSTON, J. *Métodos econométricos*, Tradução de Seiki Kaneko Endo, São Paulo: Atlas, 1971.

KARMEL, P. H; POLASEK, M. *Estatística geral e aplicada para economistas*, Tradução de José Pereira Lima, 2ª ed. São Paulo: Atlas, 1974.

KAZMIER, Leonard J. *Estatística aplicada à economia e administração*. Tradução de Carlos Augusto Crusius, São Paulo: McGraw-Hill do Brasil, 1982.

KMENTA, Jan. *Elementos de econometria*, Tradução de Carlos Roberto Vieira de Araújo, São Paulo: Atlas, 1978.

LAPPONI, Juan Carlos. *Estatística: Usando excel 5 e 7*, São Paulo: Lapponi, 1997

LEONE, George S. G. *Curso de contabilidade de custos: contém critério do custeio ABC*. São Paulo: Atlas, 1997.

_____. *Custos: planejamento, implantação e controle*. 2. ed. São Paulo: Atlas, 1994

MATIAS, Alberto Borges. *O instituto jurídico da concordata no Brasil como instrumento de recuperação econômica e financeira das empresas*, São Paulo, 1992. 88p Tese (Doutorado) - Faculdade de Economia, Administração e Contabilidade da Universidade De São Paulo

MATOS, Orlando Carneiro de. *Econometria básica: Teoria e aplicações*, 3. ed. São Paulo: Atlas, 2000.

PEREIRA, Luiz Carlos Jacob. *Condicionantes da captação agregada dos fundos de ações*. Revista de administração – RAUSP., v. 28, nº. 2, p. 22-32, abril/junho, 1993.

ROSS, Stephen A; WESTERFIELD, Randolph W; JAFFE, Jeffrey F. *Administração financeira: corporate finance*, Tradução de Antonio Zoratto Sanvicente, São Paulo: Atlas, 1995.

SOUZA, Daisy Gomes de. *Algumas considerações sobre regressão não linear*, São Paulo, 1986. 122p Dissertação (Mestrado) – Instituto de Matemática e Estatística da Universidade de São Paulo